

준지도학습을 이용한 노이즈 데이터 학습 방법

(A Method of Learning Noisy Data using Semi-supervised Learning)

김 지 희, 박 상 기, 노 시 동, 정 기 석*
한양대학교

(Ji-Hee Kim, Sangki Park, Si-Dong Roh, Ki-Seok Chung)
(Hanyang Univ., Seoul)

Abstract : One of the major problems of modern neural networks is that models are vulnerable to data noise. In order to resolve this concern, research on removing noisy data has been actively conducted. However, there is a limitation that information in the removed noisy cannot be utilized for learning. In this paper, we propose an effective learning method based on FixMatch, one of the widely-used semi-supervised learning methods, and devise additional techniques that are effective for noisy labels such as model ensemble and parameter scheduling. Our experiments show that the proposed method achieves the best accuracy under every noise rate condition verifying that the proposed model is robust to data noise.

Keywords : Noise, Noisy data, Cloud, Semi-supervised learning, EMA

I. 서 론

데이터 레이블링 과정은 인간에 의해 진행되므로 그 과정에서 오류가 일어날 가능성이 존재한다. 일반적으로 딥러닝 모델은 올바르게 학습된 레이블, 즉 노이즈가 포함된 데이터를 기반으로 학습하게 되면, 성능이 저하될 수 있다. 이 문제를 해결하기 위해서 noisy 데이터를 탐지해서 제거하거나 noisy 데이터 하에서도 강인하게 동작하는 모델들이 연구되었다 [1]. 그러나 전자는 중요한 자원인 데이터를 제거해야 해서 충분한 양의 데이터 정보를 활용하지 못한다는 점에서 한계가 있고, 후자는 훈련 데이터나 노이즈의 종류에 의존적이어서 깨끗한 검증 데이터와 같은 사전 정보가 있어야 한다는 단점이 있다 [2].

준지도학습은 일부 데이터의 label이 없어도 이미지의 정보만으로 모델을 학습시킬 수 있는 학습 기법이다. 이에 착안하여 본 논문에서는 noisy

labeled 데이터를 제거하는 대신, 준지도학습 중 하나인 FixMatch [3]를 사용하여 noisy 데이터를 unlabeled 데이터로 활용함으로써 분류 성능을 향상시켰다. 이 때 noisy label을 판단하는 과정에서 기존 FixMatch 모델과 지수이동평균(Exponential Moving Average, EMA) 모델을 앙상블하여 더 나은 예측을 얻는 방법을 제안한다.

II. 관련 연구

1. Noisy Label




그림 1. Noisy Label 예시

Fig. 1. Example of noisy label

Noisy label이란 올바르게 학습된 데이터 레이블을 의미하며, 데이터 노이즈 중 하나이다. Noisy label은 또 다른 데이터 노이즈의 종류인 feature noise보다 학습에 더 큰 해를 끼치는 것으로 알려져 있다 [1]. 이미지를 예로 들었을 때, feature는 일부의 픽셀들이 왜곡되어도 다른 픽셀

*Corresponding Author (kchung@hanyang.ac.kr)

김지희, 박상기, 노시동, 정기석: 한양대학교

※ 이 논문은 2021년도 정부 (과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원 (No.2021-0-00131, 제조검사장비 경량화를 위한 지능형 엣지컴퓨팅 반도체 개발)을 받아 수행된 연구임.

들의 정보가 존재하지만, label은 유일한 정보이기 때문에 상대적으로 큰 정보 손실이 발생한다.

2. Noisy Label을 제거하는 방법

노이즈가 많은 데이터로 모델을 학습하는 방법은 크게 두 가지가 있다. 첫 번째는 noisy label에서도 잘 동작하는 강인한 모델을 학습시키는 것으로, 정규화 또는 손실 함수를 도입하여 noisy label에 과적합되지 않도록 한다. 두 번째 방법은 noisy label일 확률이 높은 데이터를 탐지 및 제거한 후 남은 깨끗한 데이터로 모델을 훈련시키는 것이다.

Noisy label일 가능성이 높은 데이터를 제거하는 방법을 제안한 논문은 다음과 같다. Han et al.의 co-teaching [4]은 두 네트워크가 함께 학습되며 한 네트워크가 다른 네트워크의 학습에 사용할 데이터를 선택하여 노이즈가 많은 데이터를 감지하는 데 도움을 주었다. Huang et al.의 O2U-Net [5]에서는 매개 변수인 학습률을 변경하는 것만으로 과소적합(Underfitting)에서 과적합으로 진행되는 학습을 여러 번 반복하였고, 데이터 별 손실의 평균을 계산하여 noisy label을 선택에 신뢰성을 높였다.

Zhou et al.[6]에서는 손실의 평균을 EMA를 사용해서 계산함으로써 단순 평균보다 noisy label을 더 안정적으로 판단하였다. 본 논문에서는 순간적인 값보다 EMA로 축적된 값을 사용했을 때 편차가 적은 결과를 생성하는 것에 착안하여 파라미터 EMA를 통해 분류 성능 향상을 확인하였다.

III. 본 론

1. FixMatch

준지도학습은 레이블링된 데이터에 대하여 레이블링되지 않은 데이터의 도움도 받음으로써 지도학습보다 나은 성능을 내고자 하는 학습 방법이다. 그 중에서도 FixMatch는 Consistency regularization과 유사 레이블링(Pseudo-labeling)을 사용한 준지도학습 방식이며 손실함수는 식(1)과 같다.

레이블링된 데이터(x_l)는 지도학습으로 학습되어 레이블 손실(l_s)을 생성한다. 레이블링되지 않은 데이터(x_u)는 먼저 약하게 변형한 후 추론하여 유사 레이블(q)을 생성하고, 이는 강하게 변형된 데이터를 학습할 때 타겟값으로 사용되었다.

식 1 : FixMatch 손실 함수

$$\begin{aligned} l_s &= H(y, p(\bar{y}|x_l)) \\ l_u &= H(q, p(\bar{y}|A(x_u))) \\ l &= l_s + \lambda l_u \end{aligned} \quad (1)$$

유사 레이블과 타겟값 사이의 손실(l_u)을 계산하고, 두 손실을 더한 것이 FixMatch의 최종 손실 함수이다. 본 논문에서는 이에 착안하여 올바른 데이터는 지도학습, noisy 데이터는 레이블을 제거하여 FixMatch 방식의 준지도학습을 통해 분류 성능을 향상시켰다.

Algorithm 1: Learning Noisy Data using Semi-supervised Learning

```

1 Input: noisy dataset D, remove rate p, initial loss weight  $\lambda_s$ ,
  augmentation strategies (weak, strong)
2 Step 1: Select clean data from dataset D
3 for epoch  $\leftarrow 0$  to total_epoch do
4   compute loss on every sample of D
5   record loss per sample
6    $l_t = l_{t-1} + l_t$ 
7 remove the label of top p% of samples with high loss
8 get new labeled (X, Y) and unlabeled dataset ( $X_u$ )
9 Step 2: Train model with ensemble FixMatch
10 for epoch  $\leftarrow 0$  to max_epoch do
11   for j  $\leftarrow 0$  to batches do
12     compute loss on  $X_l : l_{labeled}$ 
13      $logit_1 = model(weak(X_u))$ 
14      $logit_2 = EMA(weak(X_u))$ 
15     ensembled logit  $l_e = (logit_1 + logit_2)/2$ 
16     compute loss on (strong( $X_u$ ),  $l_e$ ) :  $l_{unlabeled}$ 
17      $\lambda \leftarrow Step(\lambda_s, epoch)$ 
18      $l = l_{labeled} + \lambda * l_{unlabeled}$ 
19     update weights
    
```

그림 2. 제안하는 알고리즘 설명

Fig. 2. Description of the proposed Algorithm

2. 제안 방법

그림 2는 제안하는 알고리즘을 표현한 의사 코드이다. 준지도학습 전, noisy하지 않은 데이터를 선택하기 위해서 모든 데이터를 학습시킨 후, 손실 값 상위 p%의 데이터의 레이블을 제거하여 unlabeled 데이터셋을 생성하고, 나머지를 labeled 데이터로 선정한다. 본 논문에서는 제거 비율 p는 90%로 사용하였다.

데이터는 매 반복마다 labeled와 unlabeled 데이터를 합친 전체 데이터셋에서 배치 단위로 모델에 입력되어 학습이 진행된다. Labeled 데이터는 지도학습을 통해 레이블 손실을 생성하고, unlabeled 데이터는 그림 2에 따라 unlabeled 손실을 생성한다. 먼저 동일한 이미지가 서로 다른 증강 기법을 통해 모델에 입력된다.

식 2 : EMA 모델 파라미터 생성 식

$$\theta'_t = \alpha\theta'_{t-1} + (1-\alpha)\theta_t \quad (2)$$

약하게 변형된 이미지는 모델과 식 2에 따라 생성된 EMA 모델에 각각 입력되고, 두 예측값을 앙상블하여 유사 레이블을 만든다. 이 때 α 는 0.999로 택하였다. 식 2에서 θ' 는 EMA 모델의 파라미터, θ 는 복사될 모델의 파라미터를 의미한다.




그림 3. Unlabeled 데이터 흐름
Fig. 3. Flow of unlabeled data

표 1. 사용한 Augmentation 기법 종류

Table 1. Types of Augmentations Used

증강 정도	증강 기법 종류
Weak	RandomHorizontalFlip, RandomCrop
Strong	Weak + RandAugmentation

생성된 유사 레이블과 강하게 변형된 이미지의 예측값 사이에 손실을 계산한 후 레이블 손실과 더하여 학습에 사용할 최종 손실 값을 계산한다. 이 때 labeled 손실과 unlabeled 손실의 반영비율을 결정하는 손실 가중치 λ 는 식 3과 같이 step function을 사용하여 unlabeled 데이터의 영향이 적은 초반에는 unlabeled 손실의 영향을 크게 하고, 학습이 진행됨에 따라 줄어나가도록 했다.

식 3 : 손실 가중치 계산 식

$$\lambda = \begin{cases} \lambda_{t-1} - step & \text{if } t \% 30 = 0 \\ \lambda_{t-1} & \text{otherwise} \end{cases} \quad (3)$$

$$step = \frac{\lambda_s - 1}{\text{floor}(t_f/30)}$$

λ_s 는 시작 가중치이며 본 논문에서는 1.2를 사용하였다. t 는 현재 반복, t_f 는 총 반복 횟수를 의미한다.

3. 실험 결과

표 2. 제안하는 방법과 이전 논문들 정확도 비교

Table 2. Comparison of accuracy between the proposed method and previous papers

방법	노이즈 비율		
	20%	40%	60%
Co-Teaching	87.26	82.85	74.04
O2U-net	92.6	90.3	43.4
Mixup	94	91.5	86.8
MentorMix	95.6	94.2	91.3
Ours	96.2	94.89	92.32

표 3. Noise rate 60%에서 각 제안 방법 성능 비교

Table 3. Performance comparison of the proposed method at a noise rate of 60%

	정확도
(1) FixMatch만 사용	90.75
(2) EMA 앙상블	91.29
(3) λ 스케줄링	91.89
(2)+(3)	92.32

본 논문에서는 PyTorch 프레임워크 환경에서 ResNet50을 모델로 사용하였다. 데이터셋은 CIFAR-10을 사용하였고, 20, 40, 60%의 비율로 데이터 레이블을 다른 클래스의 레이블로 변경하였다.

표 2은 이전 noisy label 관련 논문들과 정확도를 비교한 결과이고, 표 3는 본 연구에서 제안 방법에서 적용한 각 세부 방법들을 하나씩 추가로 적용하며 성능을 평가한 것이다. 실험 결과, 모든 노이즈 비율 환경에서 기존 방식들 보다 높은 정확도를 달성했으며, 노이즈 비율이 높아질수록 비교 기법들과 비교하여, 정확도 하락 폭이 상대적으로 적어서, 60% 비율일 때, 비교 기법들 보다 높은 92.32%의 성능을 보였다.

종류별 실험을 통해 FixMatch만 사용했을 때와 비교하여, EMA 앙상블과 λ 스케줄링을 함께 적용했을 때 정확도가 1.57% 높아짐을 확인하였다.

IV. 결론

데이터 레이블링 과정은 인간에 의해 진행되므로 그 과정에서 실수가 필연적으로 발생한다. 따라서 산업에서 사용되는 딥러닝 모델은 올바르게 않은 레이블, 즉 노이즈가 포함된 데이터를 기반으로 학습하게 되면, 모델의 성능이 저하될 수 있다. 이 문제를 해결하기 위해서 noisy 데이터를 탐지해서 제거하거나 noisy 데이터의 존재 하에서도 강인하게 동작하는 모델들이 연구되었다. 하지만, 데이터를 제거하면 제거된 데이터의 정보들이 전혀 활용되지 못하며, 훈련 데이터나 노이즈의 종류에

의존적이어서 사전 정보가 필요하다는 단점이 있다.

준지도학습은 일부 데이터의 label이 없어도 이미지의 정보만으로 모델을 학습시킬 수 있는 학습 기법이다. 이에 착안하여 본 논문에서는 noisy labeled 데이터를 제거하는 대신, 준지도학습 중 하나인 FixMatch를 사용하여 noisy 데이터를 unlabeled 데이터로 활용함으로써 분류 성능을 향상시켰다. 각 제안한 방법인 FixMatch, 앙상블, λ 스케줄링을 사용했을 때 성능이 1.57% 나아졌음을 확인하였고, CIFAR-10의 노이즈 비율이 60%이었을 때 비교 기법들 보다 높은 92.32%의 성능을 보였다.

References

- [1] Song, H., Kim, M., Park, D., Shin, Y. and Lee, J.-G. "Learning from noisy labels with deep neural networks: A survey." IEEE Transactions on Neural Networks and Learning Systems, 2022.
- [2] Patrini, G., Rozza, A., Krishna Menon, A., Nock, R., & Qu, L., "Making deep neural networks robust to label noise: A loss correction approach", In Proceedings of the IEEE conference on computer vision and pattern recognition, 1944-195, 2017.
- [3] Sohn, K., Berthelot, D., Carlini, N., Zhang, Z., Zhang, H., Raffel, C. A., Cubuk, E. D., Kurakin, A. and Li, C.-L. "Fixmatch: Simplifying semi-supervised learning with consistency and confidence." Advances in neural information processing systems, 33, 596-608, 2020.
- [4] Cook, L. and Friend, M. "Co-teaching: Guidelines for creating effective practices. Focus on exceptional children", 28, 1995.
- [5] Huang, Jinchu, et al. "O2u-net: A simple noisy label detection approach for deep neural networks." Proceedings of the IEEE/CVF international conference on computer vision, 2019.
- [6] Zhou, Tianyi, Shengjie Wang, and Jeff Bilmes. "Robust curriculum learning: from clean label detection to noisy label self-correction." International Conference on Learning Representations, 2020.